



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

공학석사 학위논문

3D 카메라와 Deep-Learning
기술을 이용한 자동 재고관리
시스템 개발에 관한 연구

Development of an Automated Inventory
Management System Using
Deep-Learning & 3D-Camera Technology

2017년 08월

서울대학교 대학원

산업공학과 전공

황 찬 호

3D 카메라와 Deep-Learning 기술을 이용한 자동 재고관리 시스템 개발에 관한 연구

지도교수 박 진 우

이 논문을 공학석사 학위논문으로 제출함
2017년 06월

서울대학교 대학원
산업공학과 전공
황 찬 호

황찬호의 석사 학위논문을 인준함
2017년 06월

위 원 장 _____ (인)

부위원장 _____ (인)

위 원 _____ (인)

국문초록

재고관리는 제조업에서 중요하게 다루어지는 주제로써 그 동안 다수의 연구가 진행되었으며, 바코드와 RFID(Radio Frequency Identification)등 새로운 기술을 이용하여 계속 발전되어 왔다. 하지만 이러한 시스템 하에서도 정보 시스템에 저장되어 있는 재고의 수량과 실제 재고창고에 존재하는 재고의 수량의 차이가 존재하는 정물불일치의 현상이 발생하고 이를 해결하기 위해 대다수의 재고창고는 명절 등 휴가기간을 이용하여 연 1~2회 재고 실사를 진행하는데 이 또한 완벽한 방법이 아니며 개선을 요한다. 따라서 새로운 기술과 방법론을 적용하여 재고관리 시스템의 개선이 필요하다.

이러한 필요성에 따라 본 연구에서는 3D카메라와 Deep Learning기술을 응용하여 새로운 재고관리 시스템을 제안하려 한다. 본 연구는 크게 세 부분으로 구성되어있다. 첫째, 3D카메라를 이용해 재고 구역의 RGB(Red-Green-Blue) & IR(Infrared)이미지를 취득하는 것. 둘째, 취득된 이미지 데이터와 Deep Learning(Convolutional Neural Network & Support Vector Machine)을 이용해 재고의 종류를 파악하는 것. 셋째, Depth 이미지를 이용해 재고의 수량을 파악하는 것이다. 본 연구는 여러 가정들과 제약들이 존재한다. 하지만 이와 같은 가정에서도 실제 산업에 적용될 수 있으리라 기대한다. 본 연구를 통해 재고관리 측면에서 전통적인 약점이었던 재고의 가시성을 증대시켜, 정물이 일치하는 자동 재고관리 시스템을 제안하고 검증하고자 한다.

주요어 : 3D-Camera, Deep-Learning, Inventory Management,
Convolutional Neural Network, Support Vector Machine

학 번 : 2015-22860

목 차

1. 서론	1
1.1 연구 배경 및 목적	1
1.2 연구의 범위	3
1.3 논문의 구성	4
2. 배경이론 및 관련연구	5
2.1 재고관리 방법론	5
2.1.1 바코드를 이용한 재고관리	5
2.1.2 RFID를 이용한 재고관리	6
2.1.3 이미지를 이용한 재고관리	7
2.1.4 기타 방법을 이용한 재고관리	8
2.2 배경이론 정리	9
2.2.1 3D카메라 원리	9
2.2.2 Support Vector Machine	10
2.2.3 Convolutional Neural Network	12
2.2.4 Cyber Physical System	13
2.2.5 Edge Detection	13
2.2.6 Camera Calibration	15
3. Deep-Learning과 3D카메라를 이용한 재고관리 제 안	17
3.1 통합 재고관리 시스템	17
3.1.1 통합 재고관리 시스템 구조	17
3.1.2 통합 재고관리 시스템 실행 방안	19

3.2 데이터 취득 및 전처리 단계	22
3.2.1 Camera Calibration	22
3.2.1 Depth Data 변환	23
3.3 데이터 분석 단계	24
3.3.1 Edge Detection을 이용한 재고구역 추출	25
3.3.2 CNN과 SVM을 이용한 재고 종류 확인	26
3.3.3 재고 개수 파악 연산	27
3.4 최종 재고량 파악 및 확인 단계	29
 4. 사례연구	 30
4.1 실험 설계	30
4.1.1 실험 개요	30
4.1.2 실험 가정 사항	30
4.2 실험 과정	31
4.2.1 실험 세팅	31
4.2.2 3D카메라를 이용한 데이터 취득 및 전처리	35
4.2.3 Deep-Learning을 이용한 재고 물품 확인	37
4.2.4 재고량 확인	39
4.3 실험 결과 분석	40
4.3.1 실험 정확도 분석	40
4.3.2 기존 재고관리 기법의 장단점	43
4.3.3 본 연구와 기존 재고관리 기법과의 비교분석	44
 5. 결론 및 추후 연구과제	 45
5.1 요약 및 연구의 의의	45
5.2 한계점	47
5.3 추후 연구 과제	48

참고문헌	50
Abstract	56

표 목 차

[표 2-1] 3D카메라 거리측정 원리 비교분석	10
[표 2-2] 윤곽선의 종류	14
[표 4-1] 실험 재고 종류	32
[표 4-2] Kinect version2 상세사양	34
[표 4-3] 실험결과 1	41
[표 4-4] 실험결과 2	42
[표 5-3] AS/RS 이동 모듈 성능	48

그 립 목 차

[그림 2-1] 2D 바코드 예시	5
[그림 2-2] 바코드를 이용한 재고관리 시스템	6
[그림 2-3] RFID를 이용한 재고관리 시스템	7
[그림 2-4] 이미지를 이용한 재고관리	8
[그림 2-5] 3D카메라의 거리측정 원리	10
[그림 2-6] SVM의 다양한 분석 형태 예시	11
[그림 2-7] CNN Design	12
[그림 2-8] 윤곽선의 종류 이미지	14
[그림 2-9] Canny Edge Detection Algorithm	15
[그림 2-10] Camera Calibration 원리	16
[그림 3-1] 재고관리 시스템에서 카메라의 이동(옆면)	18
[그림 3-2] 재고관리 시스템에서 카메라의 이동(윗면)	18
[그림 3-3] 통합 재고관리 시스템 구조	19
[그림 3-4] 통합 재고관리 시스템 실행 순서도	21
[그림 3-5] 3D카메라 Kinect version2 내부모습	22
[그림 3-6] Camera Calibration Chess-Board Patterns	23
[그림 3-7] RGB데이터와 Depth데이터의 변환	24
[그림 3-8] 재고구역을 촬영하였을 때 초기 이미지	25
[그림 3-9] 재고구역에서의 Edge detection 예시	25
[그림 3-10] Structure of the hybrid CNN-SVM model ..	26
[그림 3-11] 재고의 배열 상태	27
[그림 3-12] 재고 개수 파악에 대한 예시	28

[그림 3-13] 재고 종류 및 개수 파악에 대한 전체 시스템	29
------------------------------------	----

[그림 4-1] 실험 세팅	31
[그림 4-2] 실험 재고 종류	33
[그림 4-3] 카메라의 위치	33
[그림 4-4] Kinect version2	34
[그림 4-5] 재고 물품별 제품코드 태그	34
[그림 4-6] RGB & IR카메라로 촬영된 재고	35
[그림 4-7] IR카메라로 촬영된 이미지 변환	36
[그림 4-8] RGB & IR카메라로 촬영된 재고의 Calibration	36
[그림 4-9] 재고 구역 추출 알고리즘 적용 결과	37
[그림 4-10] 개별 재고 구분 알고리즘 적용 결과	38
[그림 4-11] 재고 물품별로 추출한 Depth 이미지	38
[그림 4-12] 태그가 부착된 재고 이미지	39
[그림 4-13] 태그 및 타이어 측면 이미지	41
[그림 4-14] 오류 발생 이미지	42

1. 서 론

1.1 연구 배경 및 목적

재고관리의 경우 대규모 재고창고 뿐만 아니라 소규모 상점에서도 이루어지고 있는 만큼 매우 많은 곳에서 이루어지고 있다. 그 중 바코드를 이용한 재고관리가 가장 흔히 사용된다. 이러한 재고 관리는 기업의 경쟁력을 결정하는 중요한 요소가 될 수 있다. 특히 고객에게 필요한 시점에 물건을 제공하기 위해서는 정확하고 신속한 재고관리가 필요하다.

하지만 재고관리를 정확하고 실시간으로 하는 것은 여러 제약이 따른다. 현재 재고관리는 바코드와 RFID기법을 이용해 진행된다. 재고가 재고창고에 들어갈 때, 재고창고에서 밖으로 반출될 때 태그를 인식하여 재고의 수량을 관리하는 방식이다. 하지만 이와 같은 방식은 재고 창고 내부에서 재고의 도난, 분실과 같은 상황이 발생하였을 때 이를 파악하기 어렵다는 문제점이 있다. 또한 이러한 문제를 인식한 재고 창고에서는 1년에 1~2회씩 정보 시스템에 있는 재고의 수량과 실제 재고 창고의 재고의 수량이 일치하는지 확인하는 “재고 실사”를 진행한다. 재고 창고에서는 수백, 수천개의 제품을 보유하고 있기에 이와 같은 재고실사를 실시하는데 있어 많은 비용과 시간이 소요된다.

이와 같은 재고 창고의 “재고 실사”과정을 대체할만한 다양한 연구들이 진행되어왔지만, 대부분의 연구들은 사람이 직접적인 개입이 필요한 연구들이다. 또한 그 정확도도 높지 않다. “재고 실사”가 진행되는 이유는 정보 시스템과 실제 재고의 수량을 100%에 가깝게 일치시키기 위해서이다. 따라서 본 연구에서 제안하는 재고관리 시스템의 경우는 재고의 종류와 수량을 100%에 가까운 정확도로 파악할 수 있어야지 의미가 있을 것이다. 이와 같은 상황을 고려하여 본 연구는 다음과 같은 목적으로 진행되었다.

- 3D카메라를 이용한 “정물일치 중심”재고관리에 대한 전체적인 시스템을 제안할 것이다. 또한 본 시스템의 경우는 사람의 개입이 최소화되며, 모든 시스템을 구축하는데 있어 현재 “재고 실사”를 진행하는 데 발생하는 비용을 단축함을 목표로 할 것이다.

- 위에서 언급한 시스템에서는 가장 중요한 것이 재고의 종류와 재고의 수량을 정확하게 파악할 수 있는지의 여부이다. 3D카메라를 이용한 취득한 RGB와 IR(적외선) 이미지 데이터를 이용해 Deep Learning과 정수 최적화 이론을 이용하여 재고의 종류와 재고의 수량을 파악하는 알고리즘을 개발하는 것을 목표로 한다.

- 전체 시스템의 유효성 검증을 통해 높은 정확도(98%~100%)로 재고의 종류와 수량을 파악할 수 있는지 검증할 것이다.

1.2 연구의 범위

본 논문에서는 다품종 대량생산하는 제품들이 보관되는 재고 창고에 한정해 적용할 수 있는 정물일치 재고관리 시스템에 한정하여 논의한다. 다품종의 의미가 다소 모호할 수 있으므로 200개 종류 미만으로 제한하고, 대량생산의 경우는 파렛트 1개(1100mm*1100mm)분량 이상일 경우 충족한다고 본다. 또한, Deep-Learning의 경우 재고의 종류를 파악 하는 데에만 적용한다.

기존에는 바코드, RFID, 음성인식 등의 기술을 이용하여 재고관리 연구가 진행되었다. 지금까지 연구된 재고관리 시스템들의 경우, 실제 재고량과 정보 시스템 상의 재고량의 차이가 있었다. 그렇기에 창고 관리자들은 재고실사 라는 것을 주기적으로 해왔다. 모든 창고에서 실 재고량과 정보시스템상의 재고량의 불일치가 발생하는 것은 아니지만, 현재까지 적용되고 있는 기술들로는 자동으로 정물일치에 관한 사항을 확인할 수 없다. 그러나 본 연구에서는 재고의 정물일치를 확인하기 위한 재고 실사 과정이 3D카메라를 이용한 재고 구역의 촬영 데이터 분석을 통해 대체될 수 있다고 가정하고 연구를 진행하고자 한다.

제안된 시스템이 실질적으로 작용할 수 있는지 확인하기 위해 제품 종류와 제품의 개수를 달리해가며 검증할 것이다. 또한 실험 결과를 바탕으로 다른 재고관리 시스템들과 비교하여 유의미한 결과가 나타나는지, 실제 재고창고에서 적용 가능한지에 대해 분석할 것이다.

1.3 논문의 구성

본 논문의 구성은 다음과 같다. 우선 2장에서는 재고관리에 대한 기존 연구들과 방법론들에 대해 분석하고 정리하였다. 또한 본 연구에서 사용할 다양한 기법들에 대한 정의와 기존 연구들을 분석하여 정리하였다. 3장에서는 Deep-Learning과 3D카메라를 이용한 재고관리에 대한 구체적인 방법과 연구에 대해 정리하였다. 본 연구의 최종적인 시스템에 대하여 서술하였고, 데이터를 취득하여 Camera Calibration등을 통한 데이터 전처리 단계를 서술하였으며 데이터 분석 단계에서 SVM(Support Vector Machine)과 CNN(Convolutional Neural Network)를 이용한 재고의 종류 파악, Edge detection을 이용한 재고의 개수 파악에 대한 방법을 제시하였다. 4장에서는 3장에서 고안한 재고관리 방안과 방법론을 검증하기 위해서 가상의 재고창고를 구성하고 재고의 종류와 수량을 정확히 파악할 수 있는지에 대해 검증하였다. 또한 한 단계 더 나아가 실험 결과를 분석하는 단계에서 다른 재고관리 기법들과의 비교분석을 통해 본 연구의 장단점에 대해 분석하였다. 5장에서는 실험 결과를 바탕으로 본 연구를 요약하고 연구의 의의에 대해 서술하였다. 끝으로, 연구의 한계점과 추후 연구과제에 대해 서술하였다.

2. 관련 연구 및 배경이론 정리

이 절에서는 기존에 존재하던 재고관리 방법론과 관련된 연구들에 대해 정리할 것이다. 또한, 본 연구에서 사용될 기법들에 대한 이론을 추가적으로 다룰 것이다.

2.1 재고관리 방법론

2.1.1 바코드를 이용한 재고관리


바코드를 이용한 재고관리 기법에 있어 바코드란 다양한 폭을 가진 검은 막대(Black Bar)와 흰 막대(White Bar)를 이용하여 2진법의 수를 표현하는 방식으로 정보를 저장하는 기술을 말한다. 바코드 기술의 경우, 종이에 단순히 인쇄함으로써 정보를 저장하고 전달할 수 있기 때문에 과거부터 현재까지 다양한 분야에 사용되고 있다. 최근 들어, 검은 막대와 흰 막대를 사용하는 것이 아닌, 검은색과 흰색의 2차원 배열을 통한 기술도 개발되었다. 다음의 [그림 2-1]은 2D 바코드의 예시를 나타내고 있다[Sriram, 1996].



[그림 2-1] 2D 바코드 예시

재고관리에 있어 바코드의 사용은 바코드 정보를 재고 물품에 붙인 후, 해당 바코드 정보가 어떠한 정보를 포함하고 있는지 스캐너를 이용해 판

독하는 방식을 사용하고 있으며, 다음의 [그림2-2]와 같은 방법으로 시스템에 적용된다.




[그림 2-2] 바코드를 이용한 재고관리 시스템 [Sriram, 1996]

2.1.2 RFID를 이용한 재고관리

RFID(Radio-Frequency Identification)을 이용한 재고관리 기법에 있어 RFID란 전파를 이용한 기술로서, 먼 거리에 있는 물체에 대한 정보 인식이 가능하게 하는 전체 시스템을 말한다. 이 시스템의 경우 전파를 방출하는 RFID태그 부분과 전파를 판독하는 RFID 판독기가 필요하다. 전파를 방출하는 RFID 태그의 경우에는, 다양한 형태의 태그가 존재하는데 크게 수동형 태그와 능동형 태그로 분류한다. 수동형 태그란 자체 동력원이 없이 RFID 판독기에 의해 유도된 전류를 이용해 전파를 방출하는 원리로 만들어진 태그를 말하며, 능동형 태그란 자체 동력원이 있어 판독기의 도움 없이 자체적으로 태그에서 전파를 방출한다. 이 외에도, 발생시키는 전파의 수파수를 가지고도 구분하기도 하는데, 다양한 분류 방법이 존재한다.

재고관리의 경우 [그림 2-3]에서와 같이 RFID 태그를 재고 물품 또는 재고 창고의 위치에 부착한다. 부착된 RFID 태그에는 해당 재고의 정보인 위치, 재고량, 입하일시 등이 저장된다. 관련 정보는 데이터베이스에 저장되어 있기에, 출하를 원할 경우 해당 구역으로 이동하여 출하를 진행하면 된다. 또한 RFID판독기를 컨베이어 벨트, AGV(Auto Guided Vehicle)와 같은 곳에 장착하여 다양한 위치에 있는 태그들을 인지하고 데이터 수정을 진행하는 등 손쉽게 관리할 수 있다. 이와 같은 방식을 으로 재고관리에 활용한다[Poon, 2009].



[그림 2-3] RFID를 이용한 재고관리 시스템 [Poon, 2009]

2.1.3 이미지를 이용한 재고관리

이미지를 이용해 재고의 개수를 파악하는 것은 사진을 통해 재고의 개

수를 파악하는 것을 의미한다. 재고파악 단계의 첫 단계로는 재고 단일 물품의 사진을 찍어 이미지를 얻고, 이를 기준 데이터로 잡는다. 이후 재고량을 파악하고자 하는 곳의 사진을 취득하여 Color histogram이라 하는 방법을 이용해 영상안의 픽셀들에 대한 분포를 분석해 재고량을 파악하게 된다. 하지만 사진을 확대할 경우 픽셀정보가 선명하지 못한 경우가 많기에, 이와 같은 경우 Spatial filter를 이용하여 상의 선명화 과정을 거쳐 최종적으로 재고의 개수를 파악하게 된다. 다음의 [그림 2-4]는 이미지를 이용한 재고수량 파악을 과정을 보여주는 예시를 나타내고 있다 [Verma, 2015].

하지만 이미지를 이용한 재고파악의 경우 3차원적으로 재고가 총 몇 개 존재하는지 파악하는 것이 아니라, 맨 앞부분에 나와 있는 재고의 개수 정도만을 파악할 수 있다는 문제점을 가지고 있으며, 빛에 큰 영향을 받기에 실제로 재고관리에 있어 사용하기에는 부족한 점이 있다.



[그림 2-4] 이미지를 이용한 재고관리 [Verma, 2015]

2.1.4 기타 방법을 이용한 재고관리

재고관리 방법론은 최근에 들어 다양한 방식으로 이루어지고 있다. 첫 번째로 음성을 이용한 재고관리 방식이다. 해당 방식의 경우 작업자가 직접 재고의 품목을 말하고 재고의 수량을 말하면 컴퓨터가 음성을 인식

하여 재고관리 데이터베이스에 정보가 저장되는 방식으로 재고관리가 진행된다.

두 번째로 무게를 이용한 재고관리 방법이다. 해당 방법의 경우 재고가 존재하는 구역에 무게를 측정할 수 있는 저울이 존재하여 재고의 수량을 파악하는데 있어 무게 정보를 이용한다[Hax, 1979].

세 번째로 드론과 카메라를 이용한 재고관리 방법이다. 철강산업과 같이 다량의 원재료를 외부에 쌓아놓는 산업의 경우, 원재료를 파악하는데 있어 사람이 직접 원재료의 부피를 추측하여 관리를 해왔다. 하지만 최근, 카메라를 Drone에 부착하여 원재료가 쌓여있는 부분의 부피를 측정하는 방식으로 재고관리를 한다.


2.2 배경이론 정리

2.2.1 3D카메라 원리

사물의 2차원적인 색상 정보만을 얻는 2D카메라와 다르게 3D카메라의 경우는 사물과의 거리(Depth)정보를 얻어 입체영상을 획득할 수 있는 카메라를 말한다. 사물과의 거리(Depth)를 취득하는 원리에는 크게 3가지가 있다. 스테레오 비전 기술, TOF(Time of Flight) 기술, 구조광 기술이다. 3D카메라는 위의 기술 중 한 가지를 채택하고 있다.

스테레오 비전 기술이란 카메라를 이용하여 얻은 2차원 정보만 있는 2장의 이미지를 가지고 양안 시차의 원리를 이용해 3차원의 거리정보를 계산해내는 기술이다. TOF(Time of Flight)기술이란 신호(근적외선, 초음파, 레이저 등)를 이용하여 신호가 사물에 반사되어 되돌아오는 시간을 계산해 사물과의 거리를 측정하는 기술을 말한다. 구조광 기술이란 점 형태의 코드화된 적외선 패턴을 비추어, 물체에 맺힌 패턴위치가 어

이에 있는지 분석하여 거리를 측정하는 기술을 말한다[김순철, 2015]. [그림 2-5]는 각 기술에 대한 원리를 보여준다. 또한 [표 2-1]은 각 기술의 장단점을 보여준다[이은주, 2013].



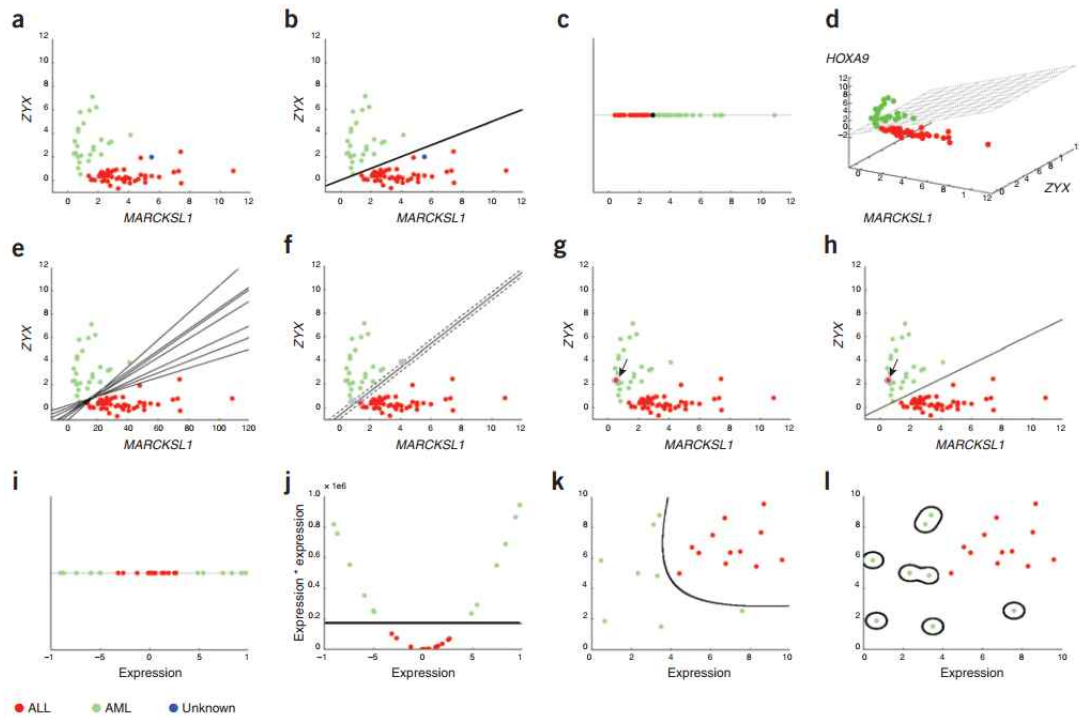
[그림 2-5] 3D카메라의 거리측정 원리

[표 2-1] 3D카메라 거리측정 원리 비교분석

	장점	단점
스테레오 비전	- 한번 촬영으로 많은 정보 취득	- 2개의 카메라가 필요 - 주변 환경요소에 취약 - 영상처리에 긴 시간소요
TOF	- 높은 정밀도 - 경제적	- 여러 개의 초음파 사용시 긴 측정시간 소요
구조광 기술	- 외부 잡음에 강함 - 빠른 영상처리	- 상대적으로 낮은 정밀도

2.2.2 Support Vector Machine

SVM(Support Vector Machine)은 특정 요소가 어느 범주에 속하는지 라벨링하는 기준을 학습하여, 어떠한 범주에 포함되는지 모르는 요소가 있을 경우, 그 요소의 범주를 자동으로 판별해내는 컴퓨터 알고리즘을 말한다. ‘요소’의 경우, 사진, 글자 등등의 다양한 형태가 될 수 있다.



[그림 2-6] SVM의 다양한 분석 형태 예시 [Noble, 2006]

SVM의 원리는 간단하다. 범주를 나눠야 하는 요소가 어떠한 특성을 가지고 있는지 추출하고, 이를 기반으로 요소들이 포함되는 범주를 구하는 것이다. 이러한 요소를 범주화하고, 구분하기 위해서는 네 가지의 단계가 필요하다[Noble, 2006].

첫째 n 차원의 공간을 나눠주는 n 차원의 평면을 구해야 한다. 예를 들어 설명하자면 [그림 2-6](a)와 같이 2차원 평면에 빨간색 범주들과 초록색 범주들이 존재한다고 가정해보자. 두 가지 범주를 [그림 2-6](b)와 같이 직선으로 구분해 줄 수 있을 것이다. [그림 2-6](c)의 경우는 1차원에서의 모습을, [그림 2-6](d)의 경우는 3차원에서의 공간을 나눠주는 평면을 표현하고 있다. 이와 같이 범주를 나누어주는 n 차원의 평면을 구해주어야 한다.


범주별로 공간을 나누어주는 n 차원의 평면이 여러 개 존재할 수 있다.

[그림 2-6](e)와 같은 상황일 경우, n 차원의 평면과 가장 가까운 점과의 거리가 가장 먼 n 차원의 평면을 선택한다는 규칙을 따른다. 결국 [그림 2-6](e)의 많은 n 차원의 평면 중 [그림 2-6](f)에서와 같이 한 개의 n 차원 평면이 선택된다. 이와 같이 n 차원의 평면을 정해준다면, 향후 발생할 수 있는 범주가 모호한 요소들에 대한 위험성을 낮출 수 있다.

셋째로, [그림 2-6](g)에서 보이는 화살표에 나타난 점과 같이 예러 요소가 존재할 수 있다. 이러한 경우, n 차원의 평면을 그리는데 있어 방해가 된다. 그렇기에, ‘soft margin’을 줌으로써, 이와 같은 예러를 배제한 채 n 차원의 평면을 구할 수 있도록 해야 한다.

마지막으로 kernel function을 적용해야 한다. kernel function이란 현재 있는 데이터의 차원을 더 높은 차원으로 만들어주는 함수를 말한다. 예를 들면, [그림 2-6](i)에서 1차원의 데이터들은 kernel function을 통해 [그림 2-6](j)와 같은 이차원 데이터로 변환될 수 있다. 이 과정을 통해, 더욱 정확하게 요소를 구분할 수 있는 n 차원의 평면을 수할 수 있을 것이다. 지금까지 말한 네 가지의 과정을 통해 SVM이라는 알고리즘이 실행될 수 있다[Osuna, 1997].

2.2.3 Convolutional Neural Network



[그림 2-7] CNN Design [Yann Lecun, 1998]

Convolutional Neural Network는 Machine Learning기법중 하나인 Artificial Neural Network기법 중 한 가지 기법이다. 보통 Neural Network를 Deep Learning이라고 명명하는데 이와 같은 Deep Learning은 Input data의 종류에 따라 범주가 나뉜다. Input data가 이미지 파일일 경우 Convolutional Neural Network를 사용하고, Time-series data의 경우는 Recurrent Neural Network를 사용하고, Unsupervised data의 경우는 Deep Belief Network를 사용한다. 이중, Convolutional Neural Network의 경우, 1998년 Yann Lecun에 의해 소개되었다. 이 기술의 경우 Gradient descent rule이라는 기법을 사용하여 이미지의 특성을 추출한다. 이를 이용해 해당 이미지의 특성을 학습한다. 계속된 학습을 통해 추후, 비슷한 특성을 가진 이미지가 들어오면, 과거 학습하였던 이미지와 같은 이미지로 판별하는 방식으로 Neural Network를 이용한다[Bergstra, 2011]. 이는 알파고의 학습에도 사용되었으며, 높은 활용도를 가지는 Neural Network이다[Yann Lecun, 1998].

2.2.4 Cyber Physical System

CPS(Cyber Physical System)이란 Computational and Physical elements를 연결해주고 이를 제어, 컨트롤 할 수 있게 만들어주는 시스템을 말한다. Embedded System과 비슷하다고 볼 수 있지만 CPS의 경우 Physical element를 Embedded System보다 비중 있게 다룬다는 점에서 다르다. CPS의 경우 실제 정보시스템에 저장되어있는 정보와 실제 정보사이의 차이가 없도록 하는데 중요한 요소이다.


2.2.5 Edge Detection

Edge Detection이란 픽셀의 밝기 또는 명암도가 임계값 보다 크게 변하는 지점을 찾는 과정을 말한다[Marr, 1980]. Edge Detection을 위해서는 윤곽선에 대해 특성을 알고, 이를 이용해 탐색해야 한다. 윤곽선은 크


게 네 가지 범주로 나눌 수 있다. [표 2-2]와 [그림 2-8]에 나타나 있듯이 루프 에지, 라인 에지, 스텝 에지, 램프 에지로 나뉜다.

[표 2-2] 윤곽선의 종류

에지 종류	설명
루프 에지	영상의 밝기가 서서히 변하다가 어느 시점 이후 다시 원래의 밝기로 서서히 돌아오는 부분
라인 에지	영상의 밝기가 갑자기 변한 뒤, 다시 돌아오는 부분
스텝 에지	영상의 밝기가 갑자기 변하는 부분
램프 에지	영상의 밝기가 점차적으로 변하는 부분




<루프 에지>



<라인 에지>



<스텝 에지>




<램프 에지>

[그림 2-8] 윤곽선의 종류 이미지

윤곽선을 검출해내는 방법론은 Sobel Operator, Robert's cross operator, Prewitt's operator, Laplacian of Gaussian and Canny Edge Detection Algorithm, 기타 등등의 다양한 방법이 있다. 가장 정확하고 많이 사용되는 방법인 Canny Edge Detection Algorithm만을 다루려 한다.

Canny Edge Detection Algorithm은 여섯 단계 과정으로 구성된다. 첫 단계는 초기 이미지의 노이즈를 걸러내는 단계이다. 둘째 단계는 경계선 강도를 찾는 과정이다. 이 과정의 이미지의 색상 변화를 이용해 찾는다. 셋째 단계는 두 번째 단계에서 계산된 경계선 강도를 이용해 윤곽선의 방향을 찾는 과정이다. 넷째 단계는 셋째 단계에서 찾아진 윤곽선들의 방향을 이용해 이미지 상에 윤곽선을 잇는 과정이다. 다섯째 단계는


Non-maximum suppression이라는 후처리 단계가 적용되고 최종적으로 마지막 단계에서 Streaking현상을 제거해주기 위해 Hysteresis를 이용한다. 이와 같은 여섯 단계의 Edge Detection검출 과정을 거치면 [그림 2-9]와 이 윤곽선이 검출된다.



[그림 2-9] Canny Edge Detection Algorithm [Canny, 1986]

2.2.6 Camera Calibration

사진 촬영으로 얻어진 이미지는 3D영역의 점들을 2D의 영역으로 변환해주는 과정으로 얻어진 결과물이다. [그림 2-10]과 같이 π_1 에서의 실제 영역의 물체를 π_2 시점의 카메라가 촬영을 하여 이미지가 발생된다 [Canny, 1986]. 하지만 이와 같은 과정을 진행할 때 3차원의 점들이 이미지 어느 부분에 맺히는지는 카메라 내부적 요소들에 의해 결정된다. 카메라에 사용된 렌즈, 카메라 렌즈와 이미지 센서 사이의 거리, 이미지 센서의 각도 등과 같은 카메라 내부적 요인에 의해 영향을 받는다. 이와 같이 카메라의 내, 외부적 특성에 의해 영향을 받는 parameter값들을 구하는 과정을 Camera calibration이라 한다[Heikkila, 1997].



[그림 2-10] Camera Calibration 원리 [Heikkila, 1997]

카메라의 내부 파라미터로는 초점거리, 주점, 비대칭계수가 있다. 카메라의 외부 파라미터로는 실제 좌표와 카메라 이지 좌표 사이의 회전 변환, 평행이동 변환 파라미터가 존재한다. 이 외부 파라미터들의 경우 내부 파라미터를 기반으로 계산할 수 있으며 카메라의 설치 방향, 위치 등의 요소들에 의해 계속적으로 바뀔 수 있다.

이와 같은 복잡한 작업을 모두 수작업으로 진행하기 어렵기에 Camera calibration을 위한 다양한 도구들이 존재한다. 대표적인 것으로 Dark Cam Calibrator, GML C++ Camera Calibration Toolbox 이 있다. 이 도구들을 이용한다면 쉽게 Parameter값들을 취득할 수 있다[Zhang, 2000].

3. Deep-Learning & 3D카메라를 이용한 재고관리 제안

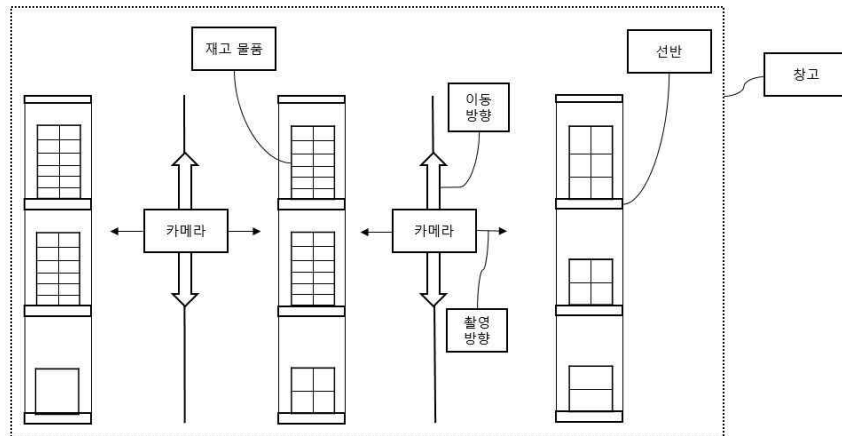
이 장에서는 3D카메라를 이용해 재고종류와 수량 파악 방법에 대한 연구를 다룰 것이다. 먼저 전체적 재고관리 시스템 구조를 구성하고, 3D카메라를 이용한 데이터를 취득하는 것에서부터 데이터를 분석하여 최종 재고 수량 파악 및 정물일치 확인까지 다룰 것이다.

3.1 통합 재고관리 시스템


3.1.1 통합 재고관리 시스템 구조

본 연구를 진행하기에 앞서, 3D카메라를 이용한 통합 재고관리 시스템 구조에 대해 구성해 보았다.

첫 단계는 재고 관리자의 명령 단계이다. 이 단계에서는 재고 관리자가 재고 파악을 위한 명령을 내리는 단계인데, 자세한 사항은 다음 절에서 다루도록 하겠다. 둘째 단계는 데이터 수집을 위한 이동 단계이다. 3D 카메라가 사진을 획득하기 위해서는 물리적으로 이동이 필요하다 [Ehrenberg, 2007]. 만약 재고창고에 AS/RS(Automated Storage and Retrieval System)가 구축되어 있다면, 해당 기기에 카메라를 설치하여 이동시킬 수 있다. AS/RS시스템의 경우 10~25km/h로 이동하기에 30fps 이상의 속도로 촬영하는 촬영기기를 이용한다면 AS/RS이동장치가 이동하며 동시에 촬영할 수 있기에 빠른 사진 획득이 가능하다. 만약 시설이 구축되어 있지 않을 경우, 드론에 카메라를 장착하여 데이터 수집 장소까지 카메라를 이동시킬 수 있다. [그림 3-1]과 [그림 3-2]에서 카메라의 이동에 따른 재고 촬영 예시를 보여주고 있다[Planning, 1958].



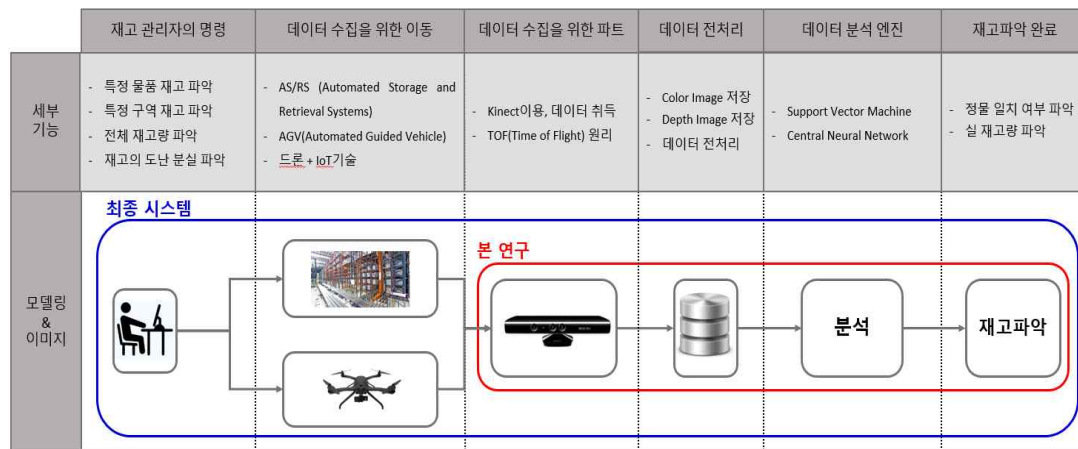
[그림 3-1] 재고관리 시스템에서 카메라의 이동(옆에서 본 모습)



[그림 3-2] 재고관리 시스템에서 카메라의 이동(위에서 본 모습)

셋째 단계는 데이터 수집을 위한 단계로써, 이동한 카메라가 RGB카메라와 IR(적외선)카메라를 이용해 촬영하여 데이터를 취득하는 과정이다. IR카메라를 이용하는 이유로는 적외선을 이용하여 물체와의 거리(Depth)를 탐색하기 위해서 사용한다. 넷째 단계는 데이터 전처리 단계이다. 이 단계에서는 취득된 RGB사진과 IR사진의 전처리 과정이 진행된다. 전처리 과정의 경우 두 종류의 카메라의 위치가 다를 뿐만 아니라 사진 사이즈도 다르기 때문에 이를 맞춰주기 위한 과정을 말한다. 다섯째 단계는

데이터 분석 단계이다. 이 단계에서는 획득한 데이터를 이용해 재고의 종류가 무엇인지, 재고의 개수가 몇 개인지 파악한다. 재고가 무엇인지 파악하기 위해서는 SVM(Support Vector Machine)과 CNN(Convolutional Neural Network)을 이용하고, 재고의 개수를 파악하기 위해서는 Edge detection을 이용한다. 자세한 내용은 다음 절에서 다루도록 하겠다. 마지막 단계인 재고파악 완료 단계에선, 중요한 재고의 경우 관리자가 취득된 데이터를 이용해 분석이 정확히 되었는지 확인하는 단계이다. 전체 과정을 표와 이미지로 정리한 것이 다음[그림 3-3]과 같다[Niu, 2012].



[그림 3-3] 통합 재고관리 시스템 구조

본 연구를 진행하는데 있어 전체 시스템의 효율성과 정확성 외에 중요한 것은 비용 문제이다. 현실적으로 재고창고에 이와 같은 시스템을 적용하기 위해서는 기존의 방법보다 비용 면에서 유리해야 한다. 본 연구에서 제안하는 전체 시스템을 구축한다면 현재 재고 실사를 진행하는데 드는 비용을 절감할 수 있으리라 기대한다. 자세한 수치분석에 대한 사항은 실제 사업화가 이루어졌을 때 가능하지만 경제성 면에서도 타당한 연구임을 밝히고자 한다.

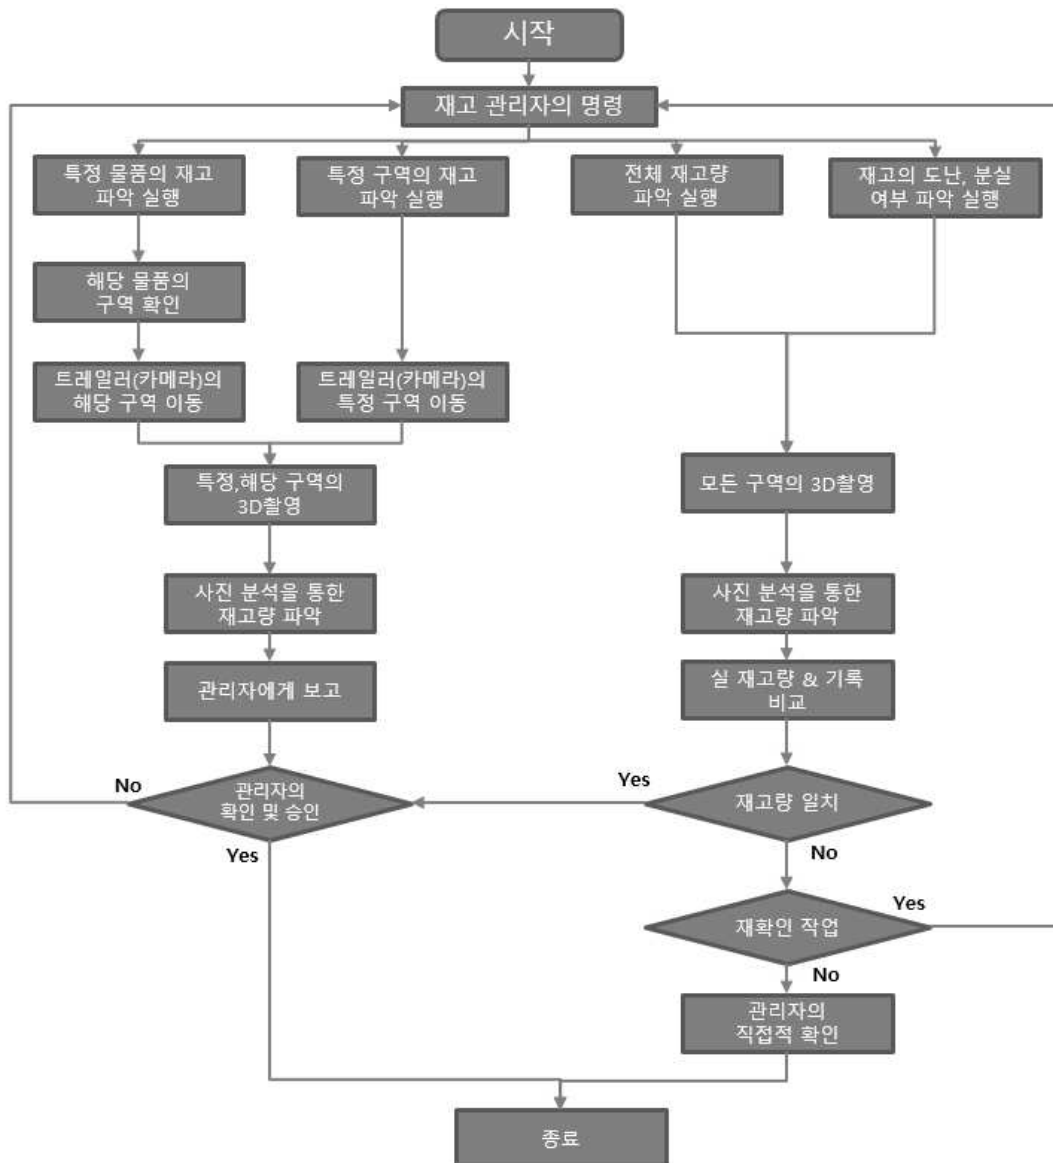
3.1.2 통합 재고관리 시스템 실행 방안

재고관리 시스템의 자동화의 최종적 목적은 관리자의 편의성을 증대시키고 관리 비용을 최소화 하는 것이다. 또한 재고관리에서 재고의 수량을 파악하는데 있어 초기 명령자인 관리자가 필요로 하는 것이 무엇인지 파악하고, 관련된 알고리즘을 구성하는 것이 매우 중요하다.

재고관리 시스템에 있어 관리자가 필요로 하는 명령으로는 크게 네 가지로 나누었다. 첫째 특정 물품의 재고 파악 실행. 둘째 특정 구역의 재고 파악 실행. 셋째 전체 재고량 파악 실행. 넷째 재고의 도난, 분실 여부 파악 실행. 다음은 각 명령의 세부사항에 대해 기술한 것이다.

- 특정 물품의 재고 파악 실행 : 특정 물품에 해당하는 구역들을 탐색해 카메라가 촬영, 분석하여 해당 물품의 총 재고량을 파악함.
- 특정 구역의 재고 파악 실행 : 특정 구역에만 한정하여 카메라가 촬영, 분석하여 해당 구역의 재고량을 파악함.
- 전체 재고량 파악 실행 : 전체 구역을 카메라가 촬영, 분석하여 전 구역의 재고량을 파악하여 데이터베이스에 저장함.
- 재고의 도난, 분실 여부 파악 실행 : 전체 구역을 카메라가 촬영, 분석하여 현 재고량을 확인하고 데이터베이스에 저장되어있는 정보와 일치하는지를 확인하여 도난, 분실을 파악함.

[그림 3-4]의 경우는 위의 4가지에 해당하는 재고관리자의 명령별, 각 명령을 이행하는데 진행되는 과정을 순서도로 정리한 것이다.




[그림 3-4] 통합 재고관리 시스템 실행 순서도

3.2 데이터 취득 및 전처리 단계

이 절에서는 재고수량과 종류를 파악하기 위해, 3D카메라를 이용해 얻어진 데이터를 전 처리하는 과정에 대해 기술하고자 한다.


3.2.1 Camera Calibration

3D카메라는 다양한 형태가 존재하지만 대부분 RGB카메라와 IR카메라로 구성된다. 두 개의 카메라는 물리적으로 다른 위치에 존재하기 때문에 두 카메라를 이용한 이미지가 초점이 다른 이미지가 된다. 또한 대부분의 카메라가 RGB카메라의 해상도가 IR카메라의 해상도보다 월등히 높다. [그림 3-5]의 경우 Microsoft사의 Kinect version2를 분해한 사진이다. 해당 기기의 경우에도 RGB카메라의 해상도는 1920×1080 , IR카메라의 해상도는 512×424 이다. 이와 같이 해상도의 차이, 카메라의 위치의 차이가 존재하기에 이를 보정하여 같은 해상도의 이미지와 동일한 지점을 촬영하도록 해주는 Camera calibration이 필요하다.



[그림 3-5] 3D카메라 Kinect version2 내부모습

Camera calibration을 하기 위한 Parameter값들을 구하기 위해 Chess-Board Patterns를 이용했다. RGB카메라와 IR카메라를 이용해 [그림 3-6]과 같이 Chess-Board Patterns을 다양한 각도로 촬영한다. 이후 오픈 프로그램인 GML Camera calibration을 이용해 두 카메라의 Distortion parameters값을 얻을 수 있었다. 이 Parameters들을 가지고 카메라들 간의 Rotation행렬과 Translation벡터를 구할 수 있다. Rotation행렬과 Translation벡터의 경우, OpenCV의 CvStereoCalibrate 함수를 이용해 구할 수 있다[Douskos, 2007].




[그림 3-6] Camera Calibration Chess-Board Patterns [Douskos, 2007]

지금까지 구해진 각 카메라들의 Parameter와 카메라들 간의 Parameter를 이용해서 두 카메라가 동일한 해상도를 가지고 동일한 이미지를 얻을 수 있다. 두 개의 다른 성능과 기능을 가진 카메라를 Calibration을 통해 동일한 형태의 정보를 획득할 수 있도록 하였다. 이로써 향후 데이터 분석을 진행할 때, 수월하게 진행할 수 있게 되었다.

3.2.2 Depth Data 변환

3D카메라로 데이터 취득을 하였을 때, 취득되는 데이터는 RGB이미지, 물체와의 거리(Depth)를 나타내는 이미지가 있다. 취득된 데이터를 저장하는 방법에는 여러 가지가 있다. 모든 데이터를 데이터베이스화 시켜 row-column의 형태로 저장하는 방법, 사진으로 정보를 저장하는 방법이 있다. RGB데이터와 Depth 데이터를 데이터화 시켜 저장하는 방법의 경

우, 최종적으로 결과검증 등의 단계에서 직관적으로 확인하기 어렵다는 단점이 있다. 그렇기에 RGB데이터의 경우는 사진 그 자체로 저장하였고, Depth 데이터 또한 사진의 형태로 저장하였다. Depth 데이터의 경우 물체와의 거리가 8m 이상이라면 재고의 수량파악에 있어 의미 없는 데이터이기에 해당 픽셀은 R=0, G=0, B=0값을 주었다. 물체와의 거리가 8m이내의 데이터는 mm단위 기준으로 처리하였다. R=8000(mm)을 256으로 나눈 몫으로, G=8000(mm)을 256으로 나눈 나머지로, B=0으로 처리하여 [그림3-7]의 오른쪽과 같은 이미지를 얻을 수 있었다.



[그림 3-7] RGB데이터와 Depth데이터의 변환


데이터 분석 단계에서는 Depth 데이터가 저장된 사진을 이용해 각 픽셀별 Depth를 추출할 수 있다.

3.3 데이터 분석 단계

3D카메라를 이용해 얻어진 데이터를 이용해 재고선반위에 있는 재고의 종류가 무엇인지 탐지해내야 할 것이다. 재고의 종류를 탐지해 내었다면, 해당 선반 위에 있는 재고의 수량을 파악해야 한다. 이와 관련된 방법과 규칙을 제안할 것이다.


3.3.1 Edge Detection을 이용한 재고구역 추출

[그림 3-8]과 같이 3D카메라가 재고구역을 촬영하였을 때, 재고가 위치하는 구역과 재고가 위치하지 않는 구역을 나누어 주어야 한다. 또한 재고가 위치하는 구역에서 경계 부분이 어디인지 모서리를 추출하는 과정이 필요하다[Khoshelham, 2011].



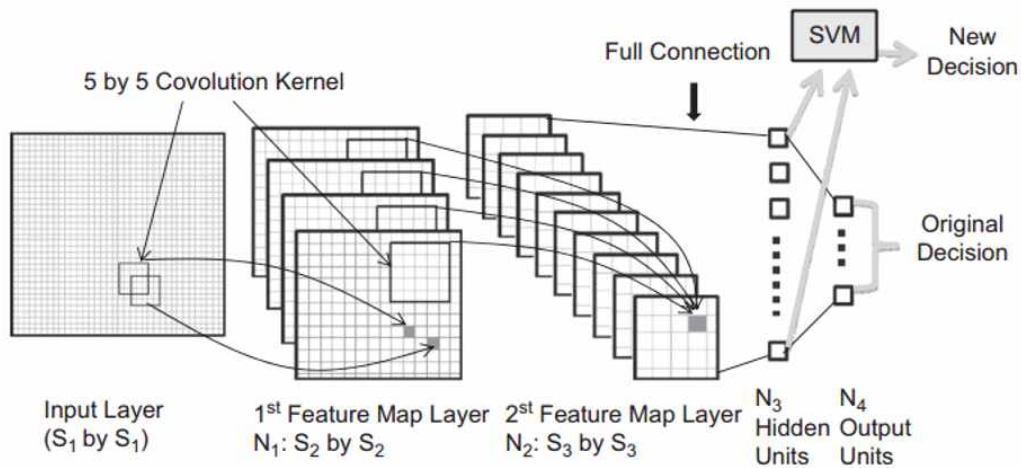
[그림 3-8] 재고구역을 촬영하였을 때 초기 이미지 [Khoshelham, 2011]

본 연구의 재고들은 스텝 에지의 Edge형태를 가진다. 그렇기에 해당 구역을 추출하는 과정은 재고 벽면 맨 안쪽과의 거리를 나타내는 픽셀과 그보다 더 가깝게 여겨지는 픽셀사이를 Edge라고 판단할 수 있다. [그림 3-9]에서 볼 수 있듯이, 이와 같은 간단한 방식으로 빨간색의 선과 같이 전체 재고의 구역을 탐지할 수 있다.



[그림 3-9] 재고구역에서의 Edge detection 예시

3.3.2 CNN 과 SVM을 이용한 재고 종류 확인



[그림 3-10] Structure of the hybrid CNN-SVM model [XX NIU, 2012]

[그림 3-10]에서는 CNN과 SVM을 이용해 이미지 데이터의 종류를 파악하는 방법론을 보여준다. 본 연구에서도 이와 같은 알고리즘을 적용한다. 먼저 재고이미지를 획득하면, 해당 이미지가 어떠한 재고인지를 파악하기 위해 SVM에 재고종류를 학습시켜야 한다. SVM에 학습시킬 이미지 특성을 추출하는데 있어 CNN을 활용한다. CNN을 이용해 재고의 특성을 추출하고 추출된 특성을 이용해 SVM의 학습 데이터로 활용하게 된다. 이후 재고구역에서 촬영되어 들어온 이미지가 어떠한 재고인지 확인하기 위해 기존에 학습된 데이터들을 이용한다[XX NIU, 2012].

본 연구에서 CNN과 SVM을 결합한 방식을 채택한 이유는 재고의 종류를 정확하게 파악하기 위해서이다. CNN을 이용한다면 재고의 특성이 가장 정확하게 파악될 수 있다. 하지만 CNN만을 활용한다면, 학습되지 않은 이미지가 들어올 경우 오류가 발생할 수 있다. 이와 같은 오류를 방지하기 위해 CNN에서 추출된 특성을 SVM에 넣어주어 종류를 파악하게 된다. SVM를 이용해 재고의 종류를 구분해낼 경우, 학습되지 않은 이미지가 들어올 때 이를 인지하기 용이하다[Osuna, 1997].

CNN만을 이용해서도 CNN과 SVM을 결합한 방식과 같은 결과를 도출

할 수 있다. 본 연구에서 CNN만을 이용해 재고의 종류를 파악하는 실험을 진행하였을 때에도 CNN과 SVM을 결합한 방식과 동일한 결과가 나왔다. 하지만 [XX NIU, 2012]논문에서 언급되어 있듯이 CNN만을 사용할 때보다 CNN과 SVM을 결합하여 이미지 분류를 진행할 때 더 높은 정확도가 나왔기에 CNN과 SVM을 결합하여 재고의 종류를 분류하였다.

3.3.3 재고 개수 파악 연산

앞부분에 있어 해당 재고구역에 존재하는 재고의 종류가 무엇인지, 재고가 어떠한 방식으로 쌓여있는지에 대해 파악할 수 있었다. 재고의 종류가 무엇인지 알 수 있다면, 해당 재고의 단일 부피를 알 수 있을 것이다. 이를 이용해 재고의 개수를 파악하여 연산하려 한다.

본 연구의 방식으로 재고의 개수를 파악하기 위해서는 먼저 몇 가지의 가정이 필요하다.

첫째 재고는 아래서부터 위로 쌓여야 하며, 벽과 가까운 쪽에서 먼저 재고를 쌓아야 한다. 즉, 정면에서 바라볼 때 재고 물품에 의해 뒷부분의 빈 공간이 가려지는 현상이 발생해서는 안 된다.

둘째 [그림 3-11]의 (b)와 같이 재고가 벽과 비스듬하게 배열되어서는 안 된다. [그림3-11]의 (a)와 같이 벽과 평행하게 배열되어야 한다.


셋째 벽과 제일 가까운 재고와의 거리가 존재한다면, 재고의 종류가 달라지더라도, 그 거리는 일정해야 한다.



[그림 3-11] 재고의 배열 상태

위와 같은 가정이 충족된다면, 3D카메라와 재고물품까지의 거리를 알

수 있을 것이다. 재고물품까지의 거리를 안다는 것은, 카메라와 가장 가까운 재고물품 뒤에 몇 개의 재고물품이 존재하는지 셀 수 있을 것이다. 이해를 돕기 위해 예를 들어 설명하도록 하겠다. 예를 들어 재고 1개의 크기는 10cm*5cm*5cm로 구성되어있다고 가정하고, 재고구역의 깊이는 50cm라고 가정하자. 아래의 [그림 3-12]가 이를 보여주고 있다.

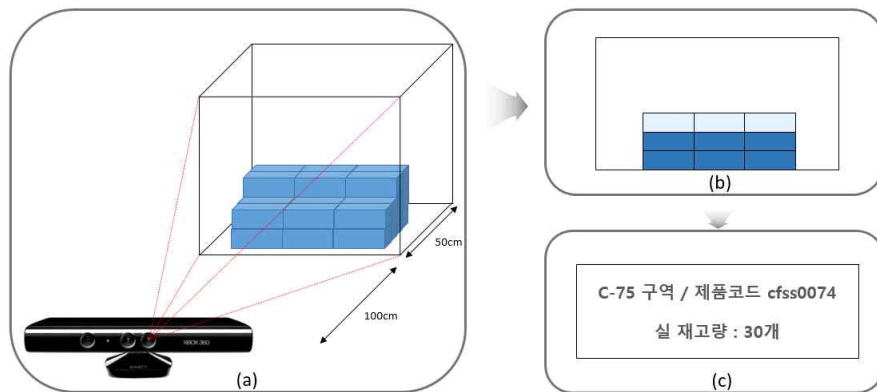


[그림 3-12] 재고 개수 파악에 대한 예시

이와 같은 상황에서, 재고구역과 100cm에서 떨어진 지점에서 3D카메라를 이용해 촬영을 하게 된다면, 물품과의 거리에 따른 데이터가 취득될 것이다. [그림 3-13]의 (a)와 같이 촬영을 하게 된다면 카메라의 방향에서 촬영한 결과가 [그림 3-13]의 (b)와 같이 나타날 것이다. 진한 파란색의 재고의 경우 카메라와의 거리가 130cm이고 하늘색 재고의 경우 카메라와의 거리가 140cm라는 정보를 얻을 수 있을 것이다. 진한 파란색의 면적을 계산한다면, $30 \times 10 = 300$ 이기에 카메라의 시점에서 재고물품 1개의 면적인 60으로 나누게 된다면 카메라와 130cm 거리에 있는 재고의 개수는 6개가 있음을 알 수 있다. 또한 카메라와 130cm의 거리에 있다는 것은 해당 재고의 뒷부분에 4개의 재고가 더 있음을 의미한다.(카메라와 재고구역 맨 뒷부분과의 거리가 150cm이기 때문) 같은 방식으로 하늘색의 면적을 계산한다면 $30 \times 5 = 150$ 이기에 카메라의 시점에서 재고물품 1개의 면적인 60으로 나누게 된다면 카메라와 140cm 거리에 있는 재고의 개수는 3개가 있음을 알 수 있다. 또한 카메라와 140cm의 거리에 있다는

것은 해당 재고의 뒷부분에 2개의 재고가 더 있음을 의미한다. 따라서 최종적으로 재고의 개수는 $6*4+3*2=30$ 개의 재고가 있음을 알 수 있다.

재고의 종류가 무엇인지 알 수 있다면, 이와 같은 방식으로 재고의 수량 또한 파악할 수 있다.



[그림 3-13] 재고 종류 및 개수 파악에 대한 전체 시스템

3.4 최종 재고량 파악 및 확인 단계

3.3단계까지 진행된다면 최종적으로 해당 재고구역에 어떠한 재고가 존재하는지, 해당 재고의 수량이 몇 개인지 까지 파악할 수 있게 된다. 하지만 만약 재고제품이 중요하여 이를 재확인하고 싶을 경우, 카메라를 이용해 취득된 데이터를 관리자가 직접 보고 자동으로 판독된 재고수량과 일치하는지 확인할 수 있을 것이다. 하지만 재고수량과 재고의 종류를 자동으로 판독하는 성능이 100%에 가깝다면, 관리자의 검토 과정은 필요 없을 것이다.

4. 사례연구

이 장에서는 3절에서 제안된 재고관리 기법에 대한 실증적 검증을 진행한다. 실제 재고창고와 비슷한 환경의 가상 재고창고를 만들어, 데이터를 취득한 후, 재고의 종류, 수량까지 파악할 수 있는지를 확인한다. 또한 한 단계 더 나아가 과거의 재고관리 기법들과 비교분석을 통해 본 연구의 우수성을 입증하려 한다.

4.1 실험 설계

4.1.1 실험 개요

실험은 크게 네 단계로 구성된다. 첫째 실험 세팅, 둘째 3D카메라를 이용한 데이터 취득, 셋째 Deep-Learning & Support Vector Machine을 이용한 재고 종류 확인, 넷째 연산을 통한 재고수량 확인으로 구성된다. 이러한 과정을 통해 최종적으로 해당 재고구역에 어떠한 재고가 있는지, 재고의 수량이 얼마인지를 파악하고자 한다. 또한 본 실험은 재고 제품에 제품 태그가 붙어있는 경우와, 붙어있지 않은 경우로 나누어 진행하였다.

4.1.2 실험 가정 사항

1.2절에 언급하였듯이, 본 연구는 모든 종류의 재고창고에서 재고의 종류와 수량을 확인할 수 있는 것이 아닌, 제한된 조건의 재고창고 재고관리로 제한한다. 그렇기에 아래와 같은 기본 가정이 필요하다.

가정1. 재고는 아래서부터 위로 쌓여야 하며, 벽과 가까운 쪽에서 먼저 재고를 쌓아야 한다.(3.3.4 참고)

가정2. 재고가 벽과 비스듬하게 배열되어서는 안 된다.(3.3.4 참고)

가정3. 벽과 제일 가까운 재고와의 거리가 존재한다면, 재고의 종류가 달라지더라도, 그 거리는 일정해야 한다.(3.3.4 참고)

가정4. 3D카메라와 재고구역과의 거리는 일정해야 한다.

가정5. 3D카메라가 촬영하는 재고구역의 영역은 일정해야 한다.

가정6. 다른 종류의 재고는 포장지의 표식 또는 포장지의 모양 등의 어떠한 형태로든지 표현되어야 한다.

가정7. 창고 전체에 있는 재고의 종류, 재고의 형태, 재고의 크기와 같은 정보는 주어지는 정보이다.

가정8. 재고 물품은 재고구역을 벗어나면 안 된다.

4.2 실험 과정

4.2.1 실험 세팅

실험을 진행하기 위해 가상의 재고창고를 구성하였다. [그림 4-1]과 같이, 재고구역은 3*3으로 총 9개가 있으며 1개의 구역의 크기는 가로 60cm, 세로 50cm 높이 60cm로 구성된다. 총 9개 구역으로 구성된 전체 크기는 가로 180cm, 세로 150cm 높이, 180cm이다.



[그림 4-1] 실험 세팅

[그림 4-2]는 재고물품에 대한 이미지를 나타내고 있다. 각 재고들의 사이즈와 재고의 형태가 다를 수 있다. 또한 같은 크기의 재고이지만 표면의 표식이 다른 경우도 존재하기에 이와 같은 상황에서 다른 재고임을 구분할 수 있는지 확인할 것이다.

[표 4-1] 실험 재고 종류

No	재고 종류	재고 규격(cm)	재고 형태
1	상자1	22*19*10	직사각형
2	상자2	28*18*16	직사각형
3	상자3	34*26*22	직사각형
4	타이어1	지름: 40 / 높이: 09	원기둥
5	타이어2	지름: 43 / 높이: 11	원기둥



[그림 4-2] 실험 재고 종류

[그림 4-3]에서는 최종적으로 재고 물품이 재고구역에 들어가 있고, 3D카메라가 어떠한 방식으로 촬영을 하는지에 대해 나타낸 것이다. 카메라의 경우, 재고구역과 0.7m떨어져 있다.



[그림 4-3] 카메라의 위치

사용하는 3D카메라로는 Microsoft사에서 나온 Kinect version2를 사용하였다. 해당 기기의 경우, RGB 카메라와 IR카메라를 모두 포함하고 있으며, 해상도도 높다. 또한 가장 중요한 가격 부분이 합리적이었기 때문에 선택하였다. [그림 4-4]는 Kinect version2를 보여주고 있으며, [표 4-2]는 해당 기기의 상세사양을 나타낸다.



[그림 4-4] Kinect version2

[표 4-2] Kinect version2 상세사양

		Kinect V2
색상(Color)	해상도(Resolution)	1920 * 1080
	FPS	30fps * 3
심도(Depth)	해상도(Resolution)	512 * 424
	FPS	30fps
인물 영역(Player)		6명
인물 자세(Skeleton)		6명
관절(Joint)		25관절/사람
손의 개폐 상태(Hand State)		○(SDK)
심도의 취득 범위(Range of Depth)		0.5~8.0m
인물의 검출 범위(Range of Detection)		0.5~4.5m
각도(Angle)	수평(Horizontal)	70도
	수직(Vertical)	60도
틸트 모터(Tilt Motor)		×
여러 응용		○

본 실험은 제품에 태그가 붙는 경우와 붙지 않는 경우로 나뉘어서 진행하였다. 태그가 붙어있는 제품의 경우 아래와 같은 형태의 태그가 붙는다. 또한 이 태그들은 기울어져 붙기도, 뒤집어져서 붙기도 하기에 무작위로 제품에 붙여 실험하였다.

제품: A A C 1 1 2	제품: A A C 1 1 5	제품: A A W 1 1 5
제품: W W G 2 5 1	제품: A B C 1 2 3	제품: D E F 4 5 6
제품: G H I 7 8 9	제품: J K L 4 5 6	제품: M N O 4 5 6
제품: P Q R 4 5 6	제품: S T O 4 5 6	제품: V W X 4 5 6
제품: Y Z A 4 5 6		

[그림 4-5] 재고 물품별 제품코드 태그


4.2.2 3D카메라를 이용한 데이터 취득 및 전처리

[그림 4-6]의 왼쪽 이미지는 RGB카메라를 이용해 재고물품이 들어있는 재고구역을 촬영한 이미지를 나타내고 있다. [그림 4-6]오른쪽 이미지는 IR카메라를 이용해 재고물품이 들어있는 재고구역을 촬영한 이미지를 나타내고 있다.




[그림 4-6] RGB & IR카메라로 촬영된 재고

[그림 4-7]에서 IR카메라로 촬영된 이미지의 경우, 카메라와 물체와의 Depth 정보를 포함하고 있다. 이때, Depth정보를 사진에 RGB값으로 저장하기 위한 과정이 필요하다. 본 논문의 3.2.2의 방법을 이용한다. [그림 4-7]의 오른쪽 이미지는 depth정보가 RGB형태의 값으로 변환된 결과를 보여준다.



[그림 4-7] IR카메라로 촬영된 이미지 변환


IR카메라로 촬영된 Depth데이터를 변환한 이미지와 RGB카메라로 취득된 이미지의 경우 각각 512*424, 1920*1080의 다른 해상도를 가지고 있으며, 카메라의 위치가 다르기 때문에 각각의 촬영하는 이미지 일치가 되지 않는다. 해상도와 촬영 위치가 다른 두 이미지를 맞춰주기 위해 3.3.1과 같은 과정인 Calibration을 해주어야 한다. [그림 4-8]은 두 개의 다른 이미지가 Calibration과정을 거친 후, 같은 해상도와 같은 영역을 보여준다는 것을 나타낸다.



[그림 4-8] RGB & IR카메라로 촬영된 재고의 Calibration

다음 과정으로는 재고 구역만을 추출하는 과정이 필요하다. 이 과정은 Edge detection을 이용한다. 상대적으로 앞으로 나와 있는 부분만이 재


고영역이라고 판단하고, 해당 영역만 추출해준다. [그림 4-9]의 빨간색 부분은 이 과정을 통해 재고가 존재하는 구역만의 이미지를 나타낸다.



[그림 4-9] 재고 구역 추출 알고리즘 적용 결과


4.2.3 Deep-Learning 을 이용한 재고 물품 확인

재고물품의 종류를 확인하기 위해서는 재고물품 1개의 이미지를 추출해야 한다. 재고영역에 존재하고 있는 재고품들을 개별재고로 분류하기 위해 한번 더 Edge detection을 해줘야 한다. 이 과정은 재고물품에 제품번호가 태그 되어있지 않을 경우와 제품번호가 태그 되어있는 경우로 나누어 진행하였다. 먼저 제품번호가 태그 되어있지 않은 경우에는 제품과 제품 사이에 미세한 Depth의 변화를 이용해 개별 제품을 탐지한다. 제품에 제품번호가 태그 되어있을 경우에는 태그의 수와 Depth정보를 이용해 개별 제품 Edge detection을 진행해준다. [그림 4-10]에서는 재고 이미지의 개별제품 Edge detection을 한 결과를 보여준다.



[그림 4-10] 개별 재고 구분 알고리즘 적용 결과

다음으로, CNN, SVM을 이용하여 해당 구역에 존재하는 제품 종류를 확인한다. [그림 4-11]은 Depth이미지에서 개별 제품을 추출해내는 과정을 나타내고 있다.



[그림 4-11] 재고 물품별로 추출한 Depth 이미지



[그림 4-12] 태그가 부착된 재고 이미지

4.2.4 재고량 확인

재고량은 Depth이미지를 이용해 확인한다. 3.3.4와 같은 방식으로 재고의 수량을 확인할 수 있다. 4.2.3에서 확인한 재고의 종류를 가지고 재고 1개의 면적을 알 수 있다. 재고 1개의 면적을 알아낸 후 3.3.4과정을 거쳐 재고의 수량을 확인할 수 있었다. 하지만 카메라와 거리가 멀어질수록 원근법에 의해 제품의 크기가 작아 보일 수 있다. 이를 보정하기 위

해 제품별로 1열에 있을시 제품의 표면 넓이, 2열에 있을시 표면 넓이 등을 고려하여 계산하였다.

4.3 실험 결과 분석

4.3.1 실험 정확도 분석

본 연구의 실험은 크게 두 가지 방식으로 진행했다. 첫째 방식은 태그가 붙어있지 않은 재고의 수량과 종류를 파악하는 것이다. 둘째 방식은 태그가 붙어있는 재고 수량과 종류를 파악하는 것이다. 각각의 경우 50회씩 촬영하여 정확도를 측정하였다.

먼저 태그가 붙어있지 않은 재고의 수량 파악 및 종류 파악에 있어서는 [표 4-3]과 같은 결과가 나왔다. 상자 1,2,3의 경우는 100%에 근접한 확률로 재고의 종류와 수량을 파악할 수 있었다. 하지만 오류가 발생하였기에 원인을 분석해 보았다. 촬영된 Input image에서 재고 구역의 파악은 잘 되었지만, 개별 재고물품의 구역파악이 이루어지지 않아 오류가 발생함을 볼 수 있었다. 또한 이 오류로 인해 재고의 수량 파악에서도 연속적인 오류가 발생하였다.


타이어 1,2의 경우 RGB, Depth사진만을 이용해 재고의 종류를 정확하게 판단할 수 없었다. 60%~80%의 재고종류 파악 정확도가 나왔는데 이 정도의 정확도는 의미가 없기에 태그가 부착되지 않은 타이어는 자동 재고 관리를 하기에는 부적합하다고 보았다. 하지만 사용하는 장비의 정확도가 높아 타이어 옆면에 표시되어있는 타이어 정보 표식을 인식할 수 있다면 충분히 재고 종류와 수량을 파악할 수 있을 것이다.

[표 4-3] 실험 결과1

No	재고 종류	재고 종류파악	재고 수량파악
1	상자1	98%	98%
2	상자2	96%	96%
3	상자3	98%	98%
4	타이어1	-	-
5	타이어2	-	-

다음으로 태그가 붙어있는 재고의 수량 파악 및 종류 파악에 있어서는 [표 4-4]과 같은 결과가 나왔다. [그림 4-13]과 같은 태그를 모든 재고에 부착하여 실험을 진행하였다.

재고에 태그가 붙어있을 경우, 카메라는 태그를 이용해 개별 재고의 구역을 정확하게 나눌 수 있었다. 나뉜 구역에서 추출된 재고의 이미지를 이용해 재고의 종류 또한 구분할 수 있었다. 또한 본 실험의 여러 가정 하에서 재고의 수량파악도 100%에 가까운 정확도를 보임을 볼 수 있었다. 하지만 [표 4-4]의 No5, No8실험의 경우 재고 수량 정확도가 98%가 나옴을 볼 수 있는데 이는, [그림 4-14]에서 원인을 찾을 수 있다. 두 개의 재고에 붙어있는 태그가 매우 근접해 있는 노란색 영역의 이미지를 볼 수 있다. 재고의 수량을 파악하는데 있어, 본 영역을 한 개의 재로 파악하게 되어 2개의 재고를 1개로 파악하여 발생한 오류이다. 이와 같은 오류는 태그인식 알고리즘을 좀 더 세밀화 하여 해결할 수 있었다.



[그림 4-13] 태그 및 타이어 측면 이미지

[표 4-4] 실험 결과2

No	재고 종류	태그 이름	재고 종류파악	재고 수량파악
1	상자1	AAC 115	100%	100%
2	상자1	AAC 112	100%	100%
3	상자1	AAG 251	100%	100%
4	상자1	AAW 115	100%	100%
5	상자1	ABC 123	100%	100%(98%)
6	상자1	DEF 456	100%	100%
7	상자1	GHI 789	100%	100%
8	상자1	JKL 456	100%	100%(98%)
9	상자1	MNO 456	100%	100%
10	상자1	PQR 456	100%	100%
11	상자1	STU 456	100%	100%
12	상자1	VWX 456	100%	100%
13	상자1	YZA 456	100%	100%
14	상자2	WWG 251	100%	100%
15	상자3	AAC 112	100%	100%
16	타이어1	AAC 112	100%	100%
17	타이어2	WWG 251	100%	100%



[그림 4-14] 오류 발생 이미지

4.3.2 기존 재고관리 기법의 장단점

본 연구에서 진행한 재고관리 기법의 장단점을 설명하기 위해서는, 기존 재고관리 기법의 정의가 먼저 필요하다. 기존 재고관리 기법을 바코드를 이용한 재고관리, RFID를 이용한 재고관리, 이미지를 이용한 재고관리, 음성을 이용한 재고관리 네 가지가 대표적이다. 이 네 가지 기법을 비교분석 하려 한다.

바코드 기술을 이용한 재고관리의 장점은 다음과 같다.

- 바코드를 재고에 붙이는데 드는 비용이 거의 없다.
- 리더기로 바코드를 읽을 때, 잘못 읽을 확률이 거의 없다.

바코드 기술을 이용한 재고관리의 단점은 다음과 같다.

- 제품에 바코드를 수작업으로 부착해야 한다.
- 제품에 부착된 바코드를 읽기 위해서는 직접 리더기를 특정 위치로 가져다 대야 한다.

RFID 기술을 이용한 재고관리의 장점은 다음과 같다.

- 한 번에 많은 재고의 수량을 파악할 수 있다.
- 빠르게 많은 재고의 수량을 파악할 수 있다.

RFID 기술을 이용한 재고관리의 단점은 다음과 같다.

- RFID태그 비용이 발생한다.
- 금속, 습도 등의 주변 환경에 영향을 받는다.

이미지를 이용한 재고관리의 장점은 다음과 같다.

- 3D카메라에 비해 상대적으로 카메라의 가격이 저렴하다.

이미지를 이용한 재고관리의 단점은 다음과 같다.

- Depth정보를 얻지 못하기에 재고의 수량을 파악하기 어렵다.
- 영상 촬영시 주변의 환경에 많은 영향을 받는다.

음성을 이용한 재고관리의 장점은 다음과 같다.

- 사람의 직접적 개입으로 인해 오류 발생시 수정이 용이하다.
- 오차 발생율이 매우 낮다.

음성을 이용한 재고관리의 단점은 다음과 같다.

- 사람이 직접 재고관리를 하는 것이기에 실질적인 자동 재고관리 시스템이 될 수 없다.

4.3.3 본 연구와 기존 재고관리 기법과의 비교분석

본 연구의 재고관리 방법론은 여러 가정 하에서 100%에 가까운 정확도를 나타낸다. 또한 바코드를 이용할 때 리더기를 바코드에 직접 가져다대는 번거로움이 필요 없다. RFID기술처럼 모든 재고에 태그를 부착할 필요도 없다. 또한 이미지를 이용한 재고관리와는 다르게 IR카메라를 이용해 Depth정보를 취득할 수 있어 재고의 수량을 정확하게 파악할 수 있다.

여러 가정 하에서 연구와 실험이 진행되었지만 이후 더 발전된 카메라를 이용하고, 높은 민감도를 가진 분석 알고리즘을 적용한다면 본 연구와 같은 방식을 이용해 자동 재고관리 시스템을 구축할 수 있을 것이다.

5. 결론 및 추후 연구과제

5.1 요약 및 연구의 의의

기존의 재고관리는 대부분 제품의 입고, 출고시 수량을 확인하여 진행하였다. 하지만 입출하시의 오류, 재고의 도난 등등의 오차가 발생할 수 있기 때문에 재고창고들은 1년에 2회 가량 재고실사를 진행한다. 이와 같은 재고실사 비용을 줄이기 위해 바코드, 음성인식, 이미지, RFID등을 도입하여 재고관리를 하는 다양한 연구가 진행되어왔다. 하지만 이에 대한 정확도가 아직 낮기 때문에 RFID기술과 3D카메라를 결합한 새로운 재고관리 시스템을 구성하고 3D카메라를 이용한 재고관리 기법이 유효한지 검증하는 연구를 진행하였다.

3D카메라를 이용한 재고관리는 총 6가지의 파트로 분류되어있다. 재고관리자의 명령, 데이터 수집을 위한 이동, 데이터 수집을 위한 파트, 데이터 전처리 파트, 데이터 분석 엔진, 재고정보가 저장된 데이터베이스와 정물일치 확인 단계로 구성된다. 이 중, 뒤의 4가지 파트에 대한 연구를 진행하였다. 데이터 수집을 위한 파트에서는 3D카메라를 이용한 Time of Flight원리를 이용한 재고와의 Depth데이터와 RGB이미지 데이터를 취득한다. 데이터 전처리 파트에서는 취득한 이미지 파일을 분석하기 위해 RGB이미지와 Depth이미지의 Calibration을 진행해준다. 데이터 분석 엔진에서는 Deep Learning을 이용해 재고의 종류가 무엇인지 파악하고, Depth 데이터를 이용해 재고의 수량을 파악한다. 마지막으로 실 재고량과 데이터베이스에 저장되어있는 재고의 수량이 일치하는지 확인한다.

시뮬레이션을 통한 실험 결과, 재고에 태그가 붙어있을 경우와, 태그가 붙어있지 않은 경우에 있어 재고의 종류와 수량을 파악하는데 100%에 가까운 정확도를 보여줌을 보일 수 있었다. 또한 모든 재고관리 과정을 사람의 개입 없이 자동으로 이루어지는 시스템이 작동함을 보일 수 있었

다.

3D카메라와 Deep Learning을 결합한 재고관리 기법은 재고파악의 목적에 따라 활용될 수 있다. 특정 물품의 재고 파악 실행, 특정 구역의 재고 파악 실행, 전체 재고량 파악 실행, 재고의 도난 분실 여부 파악 실행. 네 가지 목적으로 분류하였고 본 연구가 완료된다면 재고 관리자의 필요에 따라 빠른 재고수량 파악을 진행할 수 있을 것이다. 특히 낮은 비용으로 실시간으로 재고의 수량을 파악할 수 있기에 도난과 같은 중대한 사건이 발생함을 빠르게 확인할 수 있다. 또한 연간 1~2회 시행되는 재고실사를 진행할 필요가 없어진다. 재고 관리가 상대적으로 힘든 대형 재고 창고에서는 본 연구의 효과가 더욱 두드러지게 나타날 것이다.

5.2 한계점

본 연구는 3D카메라를 이용해 재고구역을 촬영하는데 있어 여러 가정이 적용된다. 하지만 실제 재고 창고에서는 이와 같은 가정이 지켜질 수 없다. 만약 본 연구에서 만든 가정과 같은 환경이 아닐 경우, 제안한 자동 재고 관리 시스템에서 재고의 종류와 재고의 수량을 파악하는데 그 정확도가 낮아질 것이라는 한계점이 존재한다.

또한 실험에서 사용된 재고의 종류가 상자와 타이어로 한정되어 있기 때문에 다른 종류의 재고를 대상으로 실험할 경우 알고리즘의 성능이 달라질 수 있다.

5.3 추후 연구 과제

본 연구에서는 3D카메라를 이용한 자동 재고관리 시스템에 있어 재고의 종류와 수량을 파악하는 부분을 연구하였다. 향후 연구에서는 3D카메라를 재고창고의 특정 영역까지 AS/RS System 또는 Drone을 이용해 이동시키는 과정까지 포함한 전체 시스템이 구축 가능한지에 대해 문제를 확장하여 연구를 수행할 예정이다.

또한 본 연구에서는 3종류의 박스와 2종류의 타이어만을 가지고 실험을 진행하였다. 하지만 실제 재고창고에서는 재고의 종류가 매우 다양하다. 따라서 재고의 모양과 형태가 다양한 여러 경우들에 대해서도 실험을 진행할 예정이다.

확장된 연구에서는 본 연구에서 활용한 Convolutional Neural Network의 한 단계 발전된 것인 One shot learning기법을 사용할 것이다. One shot learning기법을 사용한다면, 한 개의 재고 이미지만 있어도 Convolutional Neural Network를 이용해 모든 학습을 진행할 수 있다는 이점이 있다. 더욱 빠른 학습이 가능해지게 된다.

[표 5-3] AS/RS 이동 모듈 성능[김용태, 2012]

제품	Mustang TGW	SR-M300/2 Dematic	SMC-1XL Schaffer	Tornado Swisslog	SMC 신흥기계
주행속도	6m/s	4m/s	5m/s	6m/s	3m/s

추후 다룰 연구에서는 3D카메라의 이동까지도 고려한 연구가 진행되어야 한다. 만약 재고창고에 AS/RS시스템이 존재할 경우 3D카메라가 AS/RS시스템에 부착하여 이동한다. 본 연구에서 실험을 진행한 Kinect version2의 경우는 영상의 촬영속도가 30fps이기에 AS/RS시스템의 속도가 30km/h만 넘지 않는다면 카메라가 이동 중에도 유효한 재고 이미지

를 촬영할 수 있다. AS/RS시스템의 이동 모듈 성능은 [표 5-3]과 같다. 대부분의 모듈 이동 속도가 20km/h이기에 3D카메라가 모듈에 달려 이동하더라도 유효한 이미지를 촬영할 수 있다. 하지만 이는 수치적 계산에 불과한 것이다. 이와 관련된 실험이 추가적으로 진행되어야 할 것이다.

끝으로 본 연구에서는 재고가 재고영역에 있을 때만 해당 재고의 종류와 수량을 파악할 수 있었다. 향후 연구에서는 재고창고 내부에 재고가 존재한다면 어느 위치에 있든지 그 종류와 수량을 자동으로 파악할 수 있는 것이 가능하도록 연구를 진행할 것이다.

참 고 문 헌

<국내 문헌>

- 김대홍. (2000). 국내 상장기업의 재고관리 성과에 관한 연구. *산업경영시스템학회지*, 23(58), 101-111.
- 김순석, 김동호, & 김영훈. (2009). RFID 기반의 재고 관리 및 위치 추적 시스템. *한국정보기술학회논문지*, 7(3), 116-124.
- 김순철, & 이수영. (2015). 레이저 구조광 영상기반 거리측정 센서 개발. *제어로봇시스템학회 논문지*, 21(4), 309-314.
- 김인중. (2014). Deep Learning: 기계학습의 새로운 트렌드. *한국통신학회지 (정보와통신)*, 31(11), 52-57.
- 오영진. (2001). 이미지처리에 의한 부품관리 디지털정보화 방안에 관한 연구. *한국산업정보학회논문지 제*, 6(2).
- 윤태복, 이지형, & 조경래. (2013). Support Vector Data Description (SVDD) 가중치를 이용한개선된 학습자 모델링. *정보과학회논문지: 소프트웨어 및 응용*, 40(1), 45-52.
- 이은주, 서병국, & 박종일. (2013). 모델 기반 카메라 추적에서 3 차원 객체 모델링의 허용 오차 범위 분석. *방송공학회논문지*, 18(1), 1-9.
- 최승민, 정재찬, & 장지호. (2012). 키넥트 3D 센서의 패턴 매칭 방식에 관한 연구. *대한전자공학회 학술대회*, 973-976.

<국외 문헌>

- Bengio, Y., Courville, A. C., & Vincent, P. (2012). Unsupervised feature learning and deep learning: A review and new perspectives. *CoRR*, *abs/1206.5538*, 1.
- Bergstra, J., Bastien, F., Breuleux, O., Lamblin, P., Pascanu, R., Delalleau, O., . . . Bergeron, A. (2011). *Theano: Deep learning on gpus with python*. Paper presented at the NIPS 2011, BigLearning Workshop, Granada, Spain.
- Canny, J. (1986). A computational approach to edge detection. *IEEE Transactions on pattern analysis and machine intelligence*(6), 679-698.
- Chow, H. K. H., Choy, K. L., Lee, W. B., & Lau, K. C. (2006). Design of

- a RFID case-based resource management system for warehouse operations. *Expert Systems with Applications*, 30(4), 561-576. doi:10.1016/j.eswa.2005.07.023
- Ciresan, D. C., Meier, U., Gambardella, L. M., & Schmidhuber, J. (2011). *Convolutional neural network committees for handwritten character classification*. Paper presented at the Document Analysis and Recognition (ICDAR), 2011 International Conference on.
- Denil, M., Shakibi, B., Dinh, L., & de Freitas, N. (2013). *Predicting parameters in deep learning*. Paper presented at the Advances in Neural Information Processing Systems.
- Dong, C., Loy, C. C., He, K., & Tang, X. (2014). *Learning a deep convolutional network for image super-resolution*. Paper presented at the European Conference on Computer Vision.
- Douskos, V., Kalisperakis, I., & Karras, G. (2007). *Automatic calibration of digital cameras using planar chess-board patterns*. Paper presented at the Proceedings of the 8th Conference on Optical.
- Dutta, T. (2012). Evaluation of the Kinect™ sensor for 3-D kinematic measurement in the workplace. *Applied ergonomics*, 43(4), 645-649.
- Ehrenberg, I., Floerkemeier, C., & Sarma, S. (2007). *Inventory management with an RFID-equipped mobile robot*. Paper presented at the Automation Science and Engineering, 2007. CASE 2007. IEEE International Conference on.
- Erhan, D., Bengio, Y., Courville, A., Manzagol, P.-A., Vincent, P., & Bengio, S. (2010). Why does unsupervised pre-training help deep learning? *Journal of machine learning research*, 11(Feb), 625-660.
- Hax, A. C., & Candea, D. I. (1979). *Inventory Management*. Retrieved from
- Heikkila, J., & Silven, O. (1997). *A four-step camera calibration procedure with implicit image correction*. Paper presented at the Computer Vision and Pattern Recognition, 1997. Proceedings., 1997 IEEE Computer Society Conference on.
- Hsu, C.-W., Chang, C.-C., & Lin, C.-J. (2003). A practical guide to support vector classification.
- Khoshelham, K. (2011). *Accuracy analysis of kinect depth data*. Paper presented at the ISPRS workshop laser scanning.

- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). *Imagenet classification with deep convolutional neural networks*. Paper presented at the Advances in neural information processing systems.
- Lawrence, S., Giles, C. L., Tsoi, A. C., & Back, A. D. (1997). Face recognition: A convolutional neural-network approach. *IEEE transactions on neural networks*, 8(1), 98-113.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Liu, G., & Haralick, R. M. (2000). *Two practical issues in Canny's edge detector implementation*. Paper presented at the Pattern Recognition, 2000. Proceedings. 15th International Conference on.
- Lv, Y., Duan, Y., Kang, W., Li, Z., & Wang, F.-Y. (2015). Traffic flow prediction with big data: a deep learning approach. *IEEE Transactions on Intelligent Transportation Systems*, 16(2), 865-873.
- Maini, R., & Aggarwal, H. (2009). Study and comparison of various image edge detection techniques. *International journal of image processing (IJIP)*, 3(1), 1-11.
- Marr, D., & Hildreth, E. (1980). Theory of edge detection. *Proceedings of the Royal Society of London B: Biological Sciences*, 207(1167), 187-217.
- Matsugu, M., Mori, K., Mitari, Y., & Kaneda, Y. (2003). Subject independent facial expression recognition with robust face detection using a convolutional neural network. *Neural Networks*, 16(5), 555-559.
- Meyer, D., Leisch, F., & Hornik, K. (2003). The support vector machine under test. *Neurocomputing*, 55(1), 169-186.
- Michael, K., & McCathie, L. (2005). *The pros and cons of RFID in supply chain management*. Paper presented at the Mobile Business, 2005. ICMB 2005. International Conference on.
- Mnih, V., Kavukcuoglu, K., Silver, D., Graves, A., Antonoglou, I., Wierstra, D., & Riedmiller, M. (2013). Playing atari with deep reinforcement learning. *arXiv preprint arXiv:1312.5602*.
- Mobahi, H., Collobert, R., & Weston, J. (2009). *Deep learning from temporal coherence in video*. Paper presented at the Proceedings of the 26th Annual International Conference on

Machine Learning.

- Niu, X. X., & Suen, C. Y. (2012). A novel hybrid CNN-SVM classifier for recognizing handwritten digits. *Pattern Recognition*, 45(4), 1318-1325. doi:10.1016/j.patcog.2011.09.021
- Noble, W. S. (2006). What is a support vector machine? *Nature biotechnology*, 24(12), 1565-1567.
- Osuna, E., Freund, R., & Girosi, F. (1997). Support vector machines: Training and applications.
- Planning, S. (1958). Inventory Control. *Lecture Notes in Economics and*
- Pontil, M., & Verri, A. (1998). Support vector machines for 3D object recognition. *IEEE Transactions on pattern analysis and machine intelligence*, 20(6), 637-646.
- Poon, T. C., Choy, K. L., Chow, H. K. H., Lau, H. C. W., Chan, F. T. S., & Ho, K. C. (2009). A RFID case-based logistics resource management system for managing order-picking operations in warehouses. *Expert Systems with Applications*, 36(4), 8277-8301. doi:10.1016/j.eswa.2008.10.011
- Robbins, J., Owen, J., Saraswat, D., Ehsani, R., Maja, J., Stoven, H., . . . Doane, S. (2012). *Development of an inventory management tool using visual imagery from a multi-rotor aerial platform*. Paper presented at the Proceedings of the Southern Nursery Association Annual Research Conference.
- Rosenfeld, A., & Thurston, M. (1971). Edge and curve detection for visual scene analysis. *IEEE Transactions on computers*, 100(5), 562-569.
- Saygin, C. (2007). Adaptive inventory management using RFID data. *The International Journal of Advanced Manufacturing Technology*, 32(9), 1045-1051.
- Schäfer, H., Lenzen, F., & Garbe, C. S. (2013). *Depth and intensity based edge detection in time-of-flight images*. Paper presented at the 3DTV-Conference, 2013 International Conference on.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85-117.
- Shrivakshan, G., & Chandrasekar, C. (2012). A comparison of various edge detection techniques used in image processing. *IJCSI International Journal of Computer Science Issues*, 9(5), 272-276.

- Simard, P. Y., Steinkraus, D., & Platt, J. C. (2003). *Best Practices for Convolutional Neural Networks Applied to Visual Document Analysis*. Paper presented at the ICDAR.
- Smisek, J., Jancosek, M., & Pajdla, T. (2013). 3D with Kinect *Consumer depth cameras for computer vision* (pp. 3-25): Springer.
- Socher, R., Huval, B., Bath, B. P., Manning, C. D., & Ng, A. Y. (2012). *Convolutional-Recursive Deep Learning for 3D Object Classification*. Paper presented at the NIPS.
- Sriram, T., Rao, K. V., Biswas, S., & Ahmed, B. (1996). *Applications of barcode technology in automated storage and retrieval systems*. Paper presented at the Industrial Electronics, Control, and Instrumentation, 1996., Proceedings of the 1996 IEEE IECON 22nd International Conference on.
- Sun, Y., Wang, X., & Tang, X. (2014). *Deep learning face representation from predicting 10,000 classes*. Paper presented at the Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition.
- Syed, N. A., Huan, S., Kah, L., & Sung, K. (1999). Incremental learning with support vector machines.
- Tang, Y. (2013). Deep learning using linear support vector machines. *arXiv preprint arXiv:1306.0239*.
- Tersine, R. J. (1994). Principles of inventory and materials management.
- Tong, S., & Chang, E. (2001). *Support vector machine active learning for image retrieval*. Paper presented at the Proceedings of the ninth ACM international conference on Multimedia.
- Tong, S., & Koller, D. (2001). Support vector machine active learning with applications to text classification. *Journal of machine learning research*, 2(Nov), 45-66.
- Verma, N. K., Goyal, A., Chaman, A., Sevakula, R. K., & Salour, A. (2015). *Template matching for inventory management using fuzzy color histogram and spatial filters*. Paper presented at the Industrial Electronics and Applications (ICIEA), 2015 IEEE 10th Conference on.
- Weinstein, R. (2005). RFID: a technical overview and its application to the enterprise. *IT professional*, 7(3), 27-33.
- Wijenayake, U., Choi, S.-I., & Park, S.-Y. (2016). Stereo Vision-Based 3D Pose Estimation of Product Labels for Bin Picking.

- Numerical control robot, *22*(1), 8-16.
- Wolf, W. (2009). Cyber-physical systems. *Computer*, *42*(3), 88-89.
- Zhang, Z. (2000). A flexible new technique for camera calibration. *IEEE Transactions on pattern analysis and machine intelligence*, *22*(11), 1330-1334.
- Zhang, Z. (2012). Microsoft kinect sensor and its effect. *IEEE multimedia*, *19*(2), 4-10.

Abstract

3D-Camera Inventory Management System Using Deep-Learning

Chanho Hwang
Industrial Engineering
The Graduate School
Seoul National University

Inventory management has been treated as an important subject in the manufacturing industry. There are many kinds of technologies and research using barcode and RFID(Radio Frequency identification) technology. But, most inventory warehouses check their real inventory once or twice a year in order to find calculate differences from the online inventory. To reduce this kind of effort and cost, we need a new system using other technology.

Because of this reason, this research will suggest a new inventory management system using Deep Learning, the Support Vector Machine, and 3D-Camera technology. Research consists of three main parts. First, the 3D-Camera acquires the color of the inventory color and picture of the depth. Second, it finds the inventory type using Deep-Learning and Support Vector Machine technology. Third, the system counts the inventory quantity using depth data. This research

includes some constraint conditions and assumptions. But it can be useful in real-life industry. By completing this process, we will be able to make sure that the real inventory amount and the inventory amount online correspond at all times.

keywords : 3D-Camera, Deep-Learning, Inventory Management, Cyber Physical System, Convolutional Neural Network, Support Vector Machine

Student Number : 2015-22860